



УДК 0004.032.26

DOI 10.52575/2687-0932-2021-48-4-794-801

О применении нейросетевых моделей при планировании производства ЛКМ

¹⁾ Скрипина И.И., ²⁾ Зайцева Т.В., ²⁾ Путивцева Н.П., ²⁾ Скрипин А.А.

¹⁾ Белгородский государственный аграрный университет имени В.Я. Горина
ул. Вавилова, д.1, п. Майский, Белгородский р-н, Белгородская обл., 308503, Россия

²⁾ Белгородский государственный национальный исследовательский университет,
ул. Победы д. 85, г. Белгород, 308015, Россия

e-mail: skripina@bsu.edu.ru, zaitseva@bsu.edu.ru, putivzeva@bsu.edu.ru, 1589436@bsu.edu.ru

Аннотация. Основываясь на проведенных ранее исследованиях, были использованы данные, полученные в процессе сбора и анализа статистических данных. Определены внешние и внутренние факторы, влияющие на систему. Рассмотрены методы прогнозирования, оптимально подходящие для решения задач, стоящих перед предприятием лакокрасочной отрасли. С помощью метода анализа иерархий был проведен анализ альтернативных методов прогнозирования. На основании выводов, полученных в результате анализа, были выбраны нейросетевые модели. В статье рассмотрены результаты проведенной серии экспериментов по прогнозированию выпуска продукта НЦ-132 (Выбор мастера) с помощью нейросетевых моделей. По результатам экспериментов предложена схема выбора нейросетевой модели и алгоритм ее предварительного обучения. Приведены результаты проведенных экспериментов, на основании которых в дальнейшем планируется описание функционала модуля прогнозирования, разработки технического задания и внедрения разработанной системы.

Ключевые слова: лакокрасочные материалы (ЛКМ), нейронная сеть, прогноз, сценарий.

Для цитирования: Скрипина И.И., Зайцева Т.В., Путивцева Н.П., Скрипин А.А. 2021. О применении нейросетевых моделей при планировании производства ЛКМ. Экономика. Информатика, 48(4): 794–801. DOI: 10.52575/2687-0932-2021-48-4-794-801.

On the application of neural network models in the planning of paint production

¹⁾ Irina I. Skripina, ²⁾ Tatyana V. Zaitseva, ²⁾ Natalya P. Putivtseva, ²⁾ Alexander A. Skripin

¹⁾ Belgorod State Agrarian University named after V. Ya. Gorin,
1 Vavilov St, Maysky village, Belgorod district, Belgorod region, 308503, Russia

²⁾ Belgorod National Research University
85 Pobedy St, Belgorod, 308015, Russia

e-mail: skripina@bsu.edu.ru, zaitseva@bsu.edu.ru, putivzeva@bsu.edu.ru, 1589436@bsu.edu.ru

Annotation. Based on previous studies, the data obtained in the process of collecting and analyzing statistical data were used. External and internal factors affecting the system are determined. Forecasting methods that are optimally suitable for solving the problems facing the paint and varnish industry enterprise are considered. Using the hierarchy analysis method, an analysis of alternative forecasting methods was carried out. Based on the conclusions obtained from the analysis, neural network models were selected. The article discusses the results of a series of experiments conducted to predict the release of the NC-132 product (Master's Choice) using neural network models. Based on the results of the experiments, a scheme for choosing a neural network model and an algorithm for its preliminary training are proposed. The results of the conducted experiments are presented, on the basis of which it is planned to describe the functionality of the forecasting module, the development of the terms of reference and the implementation of the developed system in the future.

Keywords: paint and varnish materials, neural network, forecast, scenario.

For citation: Skripina I.I., Zaitseva T.V., Putivtseva N.P., Skripin A.A. 2021. On the application of neural network models in the planning of paint production. Economics. Information technologies, 48(4): 794–801 (in Russian). DOI: 10.52575/2687-0932-2021-48-4-794-801.

При разработке плана производства маркетинговый отдел обычно учитывает ретроспективную информацию о производстве за предыдущие временные периоды, ситуацию на рынке продукции, включая ассортимент продукции конкурентов и их действия, особенности региона, в котором предприятие локализовано, и на основе этой информации выполняет прогнозирование требуемого объема производства продукции по видам [Сорокина, 2016]. Указанные и другие факторы, выступающие в качестве внешних и внутренних факторов рассматриваемой организации как системы, оказывают непосредственное влияние на производство продукции.

Существует ряд подходов, позволяющих построить прогноз. Но не все из этих методов могут быть использованы для анализа данных с учетом их особенностей. Так, например, при построении регрессионных моделей или моделей временных рядов для получения достоверного прогноза необходимо большое число наблюдений (количества продукции по годам) [Бабич, и др. 2018], а информацией за большой временной период организация не обладает, адаптивные модели временных рядов предназначены в основном для краткосрочного прогнозирования, не все модели позволяют учесть нелинейный характер зависимости между переменными и т. д.

В связи с этим в работе [Скрипина, и др. 2021] был проведен сравнительный многокритериальный анализ методов прогнозирования с использованием метода анализа иерархий. В качестве альтернативных методов прогнозирования были выбраны: регрессионные модели; авторегрессионные модели; модель группового учета элементов; адаптивные модели временных рядов; нейросетевые модели; модели прогнозирования на основе цепей Маркова; модели на базе классификационно-регрессионных деревьев CART [Усков, и др., 2017].

Проведенный многокритериальный анализ показал, что наиболее предпочтительным методом прогнозирования являются нейросетевые модели, которые показали наилучшие варианты по самым важным для проводимого выбора критериям (универсальность, возможность масштабирования, количество исходных данных).

Поэтому было принято решение использовать нейронные сети для прогнозирования плана выпуска продукции. На рисунке 1 представлена схема для выбора нейросетевой модели, отвечающей требованиям, предъявляемым руководством предприятия в части прогнозирования прибыли.

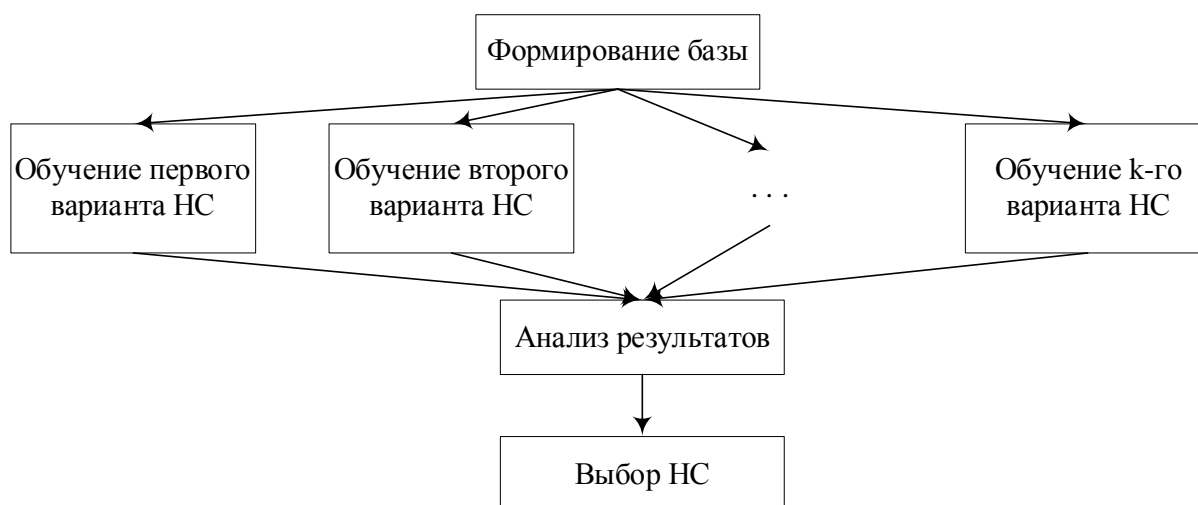


Рис. 1. Схема выбора нейросетевой модели
Fig. 1. Neural network model selection scheme

Сначала происходит формирование базы для каждого вида продукции, была отобрана следующая информация [Созуракова, 2019]:

- данные о продажах предприятия по месяцам;
- данные о продажах (наилучшие значения) из Курской (или любой другой близлежащей) области;
- данные о продажах (наилучшие значения) из Воронежской (или любой другой близлежащей) области;
- данные о продажах (наилучшие значения) по России;
- дополнительная информация, соответствующая 10 выбранным критериям, которые оказывают влияние на продажи данного продукта.

Порядок предварительного обучения каждого из вариантов нейронной сети представлен на рисунке 2.

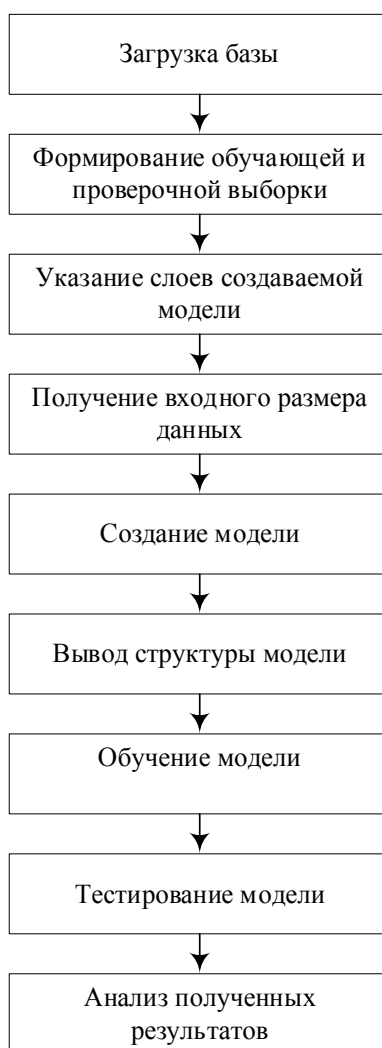


Рис. 2. Предварительное обучение i -го варианта нейронной сети
Fig. 2. Preliminary training of the i -th variant of the neural network

Далее проводится анализ результатов, полученных с помощью рассмотренных вариантов нейронных сетей, и делается заключение [Хайкин, 2019]. Для каждого вида продукции подбирается отдельная нейронная сеть, дающая некий прогноз. Затем все они сводятся в единую сеть и прогнозируют прибыль. Если прибыль не устраивает, то необходимо вносить изменения в ту ветвь общей нейронной сети, которая либо наиболее значима, либо учитывает те целевые показатели, которые менять нельзя (планы, договоры).

Рассмотрим процесс подбора нейронной сети для одного из продуктов предприятия – НЦ-132 (Выбор мастера).

На рисунке 3 представлена модель нейронной сети.




Рис. 3. Модель нейронной сети
Fig. 3. Neural network model

На вход нейронной сети подаются блоки информации в виде матриц размером 5×10 :

- первая строка – 10 элементов предыдущих записей данного предприятия;
- вторая и третья строка – по 10 элементов лучших предыдущих значений из ближайших областей (Курская и Воронежская области);
- четвертая строка – 10 элементов лучших по России;
- пятая строка 10 элементов, соответствующих 10 критериям, которые оказывают влияние на продажи данного продукта.

Далее все подготовленные данные разделяются на обучающую – 80 % и тестовую части – 20%.

В первом варианте нейронной сети была выбрана следующая последовательность слоев создаваемой модели: Выравнивающий; Полносвязный-700; Полносвязный-3.

Матрица 5×10 переводится с помощью выравнивающего слоя в запись 50×1 (столбец). Следующий слой – это полносвязный слой, размером 700×1 . Выходной слой – это столбец 3×1 , в котором первое значение – пессимистический вариант, второй – реалистический вариант, третий – оптимистический вариант прогноза.

Далее проводится обучение модели. В рассматриваемом исследовании было выбрано 20 эпох. На каждую эпоху затрачивалось от 0,47 с (максимальное время) до 0,09 с (минимальное время) машинного времени. На рисунке 4 представлены графики точности обучения для выбранного количества эпох (график точности на обучающей и на проверочной выборке).

Далее проводится тестирование модели, результаты представлены на рисунках 5–6. Как видно из рисунка 5, точность предсказаний составила 80,68 %.

На рисунке 6 представлены примеры предсказаний по выбранному продукту НЦ-132 (Выбор мастера), полученные при использовании первого варианта модели нейронной сети.

Далее была проведена серия экспериментов, в которых изменялись количество слоев нейронной сети и/или число нейронов по слоям, а также число эпох обучения (представлены результаты экспериментов, в которых были получены наибольшие значения точности предсказаний).

Эксперимент 3. Слои создаваемой модели: Выравнивающий; Полносвязный-2000; Полносвязный-3. Точность предсказаний составила 79,13 %.

Эксперимент 8. Слои создаваемой модели: Выравнивающий; Полносвязный-2000; Полносвязный-500; Полносвязный-3. Точность предсказаний составила 77,60 %.

Эксперимент 15. Слои создаваемой модели: Выравнивающий; Полносвязный-2000; Полносвязный-1500; Полносвязный-1000; Полносвязный-500; Полносвязный-250; Полносвязный-3. Точность предсказаний составила 79,94 %.

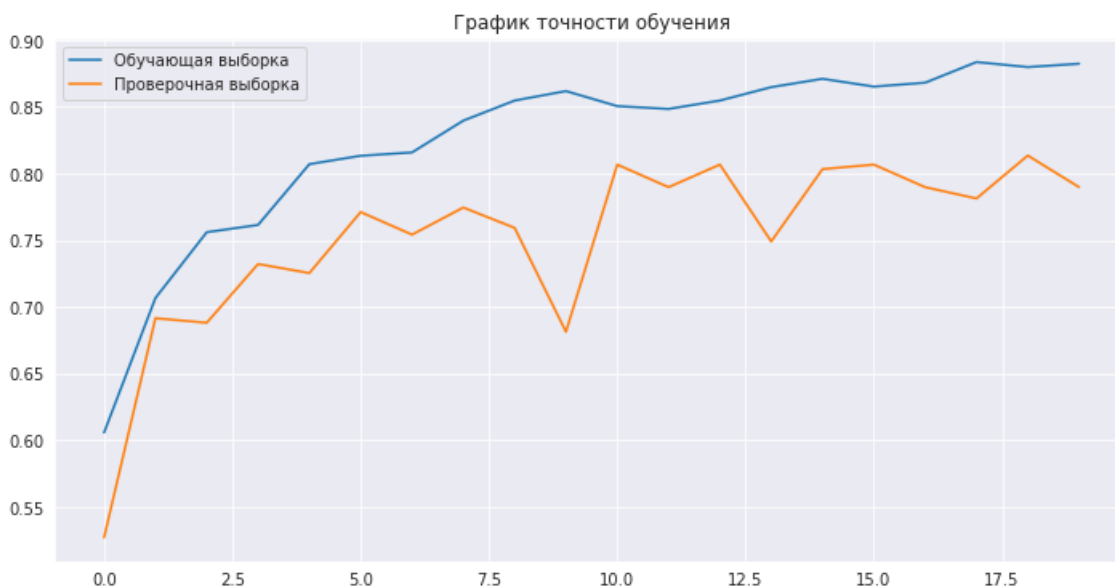


Рис. 4. Графики точности обучения
Fig. 4. Graphs of learning accuracy



Рис. 5. Характеристика полученной модели
Fig. 5. Characteristics of the resulting model




Рис. 6. Прогнозы по производству товара НЦ-132 (Выбор мастера):
а – оптимистический; б – реалистический; в – пессимистический
Fig. 6. Forecasts for the production of NC-132 goods (Master's choice):
a – optimistic; b – realistic; c – pessimistic

Также проводились эксперименты с использованием других моделей нейронных сетей. Наилучший результат был с использованием следующих слоев (рис. 7): Сверточный1D-16-5; Сверточный1D-32-5; Выравнивающий; Полносвязный-512; Полносвязный-3. Для данного варианта точность предсказаний составила 80,19 %.

Архитектура нейронной сети




Рис. 7. Модель двадцать третьего варианта нейронной сети
 Fig. 7. Model of the twenty-third variant of the neural network

На рисунке 8 представлены примеры предсказаний по выбранному продукту НЦ-132 (Выбор мастера), полученные при использовании двадцать третьего варианта модели нейронной сети.




Рис. 8. Прогнозы по производству товара НЦ-132 (Выбор мастера):
 а – оптимистический; б – реалистический; в – пессимистический
 Fig. 8. Forecasts for the production of NC-132 goods (Master's choice):
 a – optimistic; b – realistic; c – pessimistic

Проведенные исследования показали, что наилучшим из рассмотренных вариантов является первый, однако результаты тестирования в недостаточной степени отвечают требованиям, предъявляемым руководством предприятия в части прогнозирования прибыли. Поэтому в дальнейшем будет проведена доработка выбранной модели нейронной сети.

В настоящее время была проведена апробация на готовых библиотеках, которая показала удовлетворительные результаты, предварительно составлено описание функционала для дальнейшего составления технического задания и принято решение разработки модуля прогнозирования для последующего внедрения на предприятии.

Список литературы

1. Абдикеев Н.М. 2017. Долгосрочное прогнозирование макроэкономических показателей. Фундаментальные исследования, 8–1: 110–114.
2. Бабич Т.Н., Кузьбожев Э.Н., Козьева И.А. 2018. Прогнозирование и планирование в условиях рынка: Учебное пособие. М.: Инфра-М, 288 с.
3. Васильев М.Г. 2006. Состояние химического комплекса и основные направления стратегии его развития. Нефтепереработка и нефтехимия. 1: 17–21.
4. Галушкин А.И. 2015. Нейронные сети: основы теории. М.: РиС, 496 с.



5. Костюхина Г.В., Тахавова Э.Г. 2014. Разработка модели нейронной сети. В кн.: Современные инновации в науке и технике: сборник научных трудов 4-ой Международной научно-практической конференции. Курск, 17 апреля. Закрытое акционерное общество «Университетская книга»: 283–285.
6. Россия в цифрах, краткий статистический сборник. 2020. Росстат Москва: 600 с.
7. Рутковская Д., Пилинский М., Рутковский Л. 2013. Нейронные сети, генетические алгоритмы и нечеткие системы. М.: РиС, 384 с.
8. Скрипина И.И., Зайцева Т.В., Путивцева Н.П. 2021. Анализ и выбор математической модели с помощью метода анализа иерархий. Научный результат. Информационные технологии, 6–2: 41–46.
9. Созуракова С.Д., Маяк А.Н., 2019. Состояние рынка и производства лакокрасочных материалов. Отчет о НИР, ОАО «НИИТЭХИМ». М, 142 с.
10. Сорокина А.В. 2016. Становление и развитие стратегического планирования и прогнозирования в РФ. Транспортное дело России, 5: 29–31.
11. Старинский В.Н. 2017. Технологические аспекты прогнозирования рыночных ситуаций. Экономика. Бизнес. Право, 1–3 (21): 4–14.
12. Стратегия развития химической и нефтехимической промышленности на период до 2021 г. 2014. Отчет о НИР, ОАО «НИИТЭХИМ», М, 103 с.
13. Усков А.А., Кузьмин А.В. 2017. Интеллектуальные технологии управления. Искусственные нейронные сети и нечеткая логика. М.: Горячая линия –Телеком, 143 с.
14. Хайкин С. 2019. Нейронные сети: полный курс. М.: Диалектика, 1104 с.
15. Шаникова И.В. 2015. Современные проблемы прогнозирования экономического развития России. Образование и наука без границ: социально-гуманитарные науки, 1: 288–290.

References

1. Abdikeev N.M. 2017. Long-term forecasting of macroeconomic indicators. Fundamental Research, 8–1:110–114.
2. Babich T.N., Kuzbozhev E.N., Kozyeva I.A. 2018. Forecasting and planning in market conditions: Textbook. Moscow: Infra-M, 288 p.
3. Vasiliev, M.G. 2006. The state of the chemical complex and the main directions of its development strategy. Oil refining and petrochemistry. 1: 17–21.
4. Galushkin A.I. 2015. Neural networks: fundamentals of theory. М.: Fig., 496 p.
5. Kostyukhina G.V., Takhavova E.G. 2014. Development of a neural network model. In: Modern Innovations in Science and Technology: Collection of scientific papers of the 4th International Scientific and Practical Conference. Kursk, April 17. Closed Joint Stock Company "University Book": 283–285.
6. Russia in numbers, a short statistical collection. 2020. Rosstat Moscow: 600 p.
7. Rutkovskaya D., Pilinsky M., Rutkovsky L. 2013. Neural networks, genetic algorithms and fuzzy systems. Moscow: Fig., 384 p.
8. Skripina I.I., Zaitseva T.V., Putivtseva N.P. 2021. Analysis and selection of a mathematical model using the hierarchy analysis method. Scientific result. Information Technology, 6–2:41–46.
9. Sosurakova S.D., Mayak A.N., 2019. The state of the market and the production of paint and varnish materials. Research report, JSC "NIITECHIM". М.: 142 p.
10. Sorokina A.V. 2016. Formation and development of strategic planning and forecasting in the Russian Federation. Transport business of Russia, 5: 29–31.
11. Starinsky V.N. 2017. Technological aspects of forecasting market situations. Economy. Business. Law, 1–3 (21): 4–14.
12. Strategy for the development of the chemical and petrochemical industry for the period up to 2021, 2014. Research report, JSC "NIITECHIM", М.: 103 p.
13. Uskov, A.A., Kuzmin A.V. 2017. Intelligent control technologies. Artificial neural networks and fuzzy logic. М.: Hotline-Telecom, 143 p.
14. Khaykin S. 2019. Neural networks: a complete course. М.: Dialectics, 1104 p.
15. Shanikova I.V. 2015. Modern problems of forecasting the economic development of Russia. Education and Science without Borders: Social and Humanitarian Sciences, 1: 288–290.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Скрипина Ирина Ивановна, старший преподаватель кафедры математики, физики, химии и информационных технологий Белгородского государственного аграрного университета имени В.Я. Горина, п. Майский, Белгородский р-н, Белгородская обл., Россия

Зайцева Татьяна Валентиновна, кандидат технических наук, доцент кафедры прикладной информатики и информационных технологий Белгородского государственного национального исследовательского университета, Белгород, Россия

Путивцева Наталья Павловна, кандидат технических наук, доцент кафедры прикладной информатики и информационных технологий Белгородского государственного национального исследовательского университета, Белгород, Россия

Скрипин Александр Анатольевич, аспирант кафедры прикладной информатики и информационных технологий Белгородского государственного национального исследовательского университета, Белгород, Россия

INFORMATION ABOUT THE AUTHORS

Irina I. Skripina, Senior Lecturer of the Department of Mathematics, Physics, Chemistry and Information Technologies of the Belgorod State Agrarian University named after V.Ya. Gorin, Maysky village, Belgorod district, Belgorod Region, Russia

Tatiana V. Zaitseva, Candidate of Technical Sciences, Associate Professor of the Department of Applied Informatics and Information Technologies of Belgorod National Research University, Belgorod, Russia

Natalia P. Putivtseva, Candidate of Technical Sciences, Associate Professor of the Department of Applied Informatics and Information Technologies, Belgorod National Research University, Belgorod, Russia

Alexander A. Skripin, Postgraduate Student of the Department of Applied Informatics and Information Technologies of Belgorod National Research University, Belgorod, Russia